

31/11/2000

(19) 日本国特許庁 (J P)

(12) 特 許 公 報 (B 2)

(11) 特許番号

第2881711号

(45) 発行日 平成11年(1999) 4月12日

(24) 登録日 平成11年(1999) 2月5日

(51) Int.Cl. ⁶	識別記号	F I	
G 0 6 F 15/18	5 5 0	G 0 6 F 15/18	5 5 0 C
	5 2 0		5 2 0 E

請求項の数3 (全 23 頁)

(21) 出願番号	特願平2-504698	(73) 特許権者	999999999
(86) (22) 出願日	平成2年(1990) 2月21日		ハネウエル・インコーポレーテッド
(65) 公表番号	特表平4-503876		アメリカ合衆国 55408 ミネソタ州・
(43) 公表日	平成4年(1992) 7月9日		ミネアポリス ハネウエル・プラザ
(86) 国際出願番号	P C T / U S 9 0 / 0 0 8 2 8	(72) 発明者	(番地なし)
(87) 国際公開番号	W O 9 0 / 1 1 5 6 8		グーア, アローク
(87) 国際公開日	平成2年(1990) 10月4日		アメリカ合衆国 55417 ミネソタ州・
審査請求日	平成9年(1997) 1月21日		ミネアポリス・10ティエイチ アヴェニ
(31) 優先権主張番号	3 2 9, 6 2 3	(72) 発明者	ユ サウス・5104
(32) 優先日	1989年3月28日		ハーブ, ステイブ・エイ
(33) 優先権主張国	米国 (U S)		アメリカ合衆国 55108 ミネソタ州・
		(74) 代理人	セントポール・スカダー・2245
			弁理士 山川 政樹 (外4名)

審査官 立川 功

最終頁に続く

(54) 【発明の名称】 神経回路網の遺伝子的合成

1

(57) 【特許請求の範囲】

【請求項1】 選択された学習アルゴリズムおよび特定の主題を使用することに係わる神経回路網 (10) の設計を合成する方法であって、

A. 学習パラメーターを含む関係パラメーターを有する神経回路網の構造をパラメーターで表現 (20, 17) するステップと、

B. コンピュータにおいて、可能性のある神経回路網の構造を前記表現に基づいて数値例として表現し、前記パラメーターの各々がある範囲の値を共通して有する第1世代の回路網の青写真 (20) を生成するステップと、

C. 現在の世代の前記青写真に基づいてそれぞれの神経回路網の構造 (10, 19) を生成するステップと、

D. ステップCにおいて現在定義された前記神経回路網の構造 (10, 19) の各々を、前記選択された学習アルゴリ

2

ズムおよび前記特定の主題を介して訓練するステップと、

E. ステップCにおいて現在定義された前記神経回路網の構造 (10, 19) の各々の前記訓練の影響に対する受容性を試験するために、前記特定の主題に対応した試験パターンを用いて、ステップCにおいて現在定義された前記神経回路網の構造 (10, 19) の各々を試験するステップと、

F. 関心のある性能およびコストファクターに関する前記試験をした後に、ステップCにおいて現在定義された前記神経回路網の構造の各々に対する評価を実施し、この評価の結果を表すスコアを前記モデルに割り当てるステップと、

G. 前記スコアに基づいてステップCにおいて現在特定された前記神経回路網の構造から候補を選択し、この候補

に変更を加える少なくとも1つのオペレーターを適用して、前記表現に基づく現世代の回路網の青写真として特定される新しい世代の回路網の青写真(20)を生成するステップと、

H.ステップCに戻り、このプロセスを継続するステップと

を含む、神経回路網の設計を合成する方法。

【請求項2】上記オペレーターが遺伝子的オペレーターである請求項1に記載の方法。

【請求項3】選択された学習アルゴリズムおよび特定の主題を使用することに係わる神経回路網(10)の設計を合成する方法であって、

前記神経回路網の各々には：複数の計数化ユニット(18)と；入力(12)および出力層領域(16)並びにこれらの層領域の間の0またはそれ以上の隠れた層領域(14)を含む複数の段階的に配列された層領域(12,14,16)であって、各々が前記ユニット数によって定義された層領域(12,14,16)と；前記出力層領域(16)以外の前記層領域中の前記ユニットの供給群を前記入力層領域以外の前記層領域(12,14)中の前記ユニット(18)の対象群と連結する連結手段(19)であって、プロジェクションと考えられるセットにグループ化された連結手段(19)とが含まれており；前記プロジェクションの各々は前記層領域の1つからもう1つの前記層領域に延びており、

A.前記層領域の各々を特定化する部分記号列フォーマット(20,17)に、層領域パラメータスペースファイヤーと考えられる1つの第1タイプのパートおよびプロジェクションスペースファイヤーと考えられる前記プロジェクションの各々に対する少なくとも1つの第2タイプのパートを有する前記フォーマットを提供するステップを備え、

その際前記第1タイプのパートは、層領域を識別するアドレスフィールド(Address ID=)、前記ユニットの対応数を示す総サイズフィールド(Total Size=)、および前記ユニットで形成される配置を示す次元フィールドからなり、

第2のタイプのパートの各々は、主題プロジェクションと考えられる前記プロジェクションの1つに割り当てられ、前記第2タイプのタイプは前記主題プロジェクションが向けられている標的層領域と考えられる前記層領域の1つを識別する標的アドレスフィールド(Target=)、前記主題プロジェクションのアドレスフィールドのモード(Mode=)、前記主題プロジェクションに対する前記標的層領域中の対象フィールドの配置を示す次元フィールド(D=)、前記対象フィールドに対する前記主題プロジェクションの連結性を示す連結密度部分(Density=)、および少なくとも1つの学習規則パラメータフィールド(ETA=)からなり、

B.前記部分記号列フォーマットに基づきかつ関係パラ-

メーターを有する神経回路網の構造をビット記号列からなるパラメーターで表示するステップを備え、

C.コンピュータにおいて、可能性のある神経回路網の構造を前記表現(17)に基づいてビット記号列として表現し、前記パラメーターの各々がある範囲の値を共通して有する第1世代の回路網の青写真(20)を生成するステップを備え、

D.現在の世代の前記青写真に基づいてそれぞれの神経回路網の構造(10)を生成するステップを備え、

10 E.ステップDにおいて現在定義された前記神経回路網の構造の各々を、前記選択された学習アルゴリズムおよび前記主題を介して訓練するステップを備え、

F.ステップDにおいて現在定義された前記神経回路網の構造の各々の前記訓練の影響に対する受容性を試験するために、前記主題に対応した試験パターンを用いて、ステップDにおいて現在定義された前記神経回路網の構造の各々を試験するステップを備え、

G.関心のある性能およびコストファクターに関する前記試験をした後に、ステップDにおいて現在定義された前記神経回路網の構造の各々に対する評価を実施し、この

20 評価の結果を表すスコアを前記構造に割り当てるステップを備え、

H.前記スコアに基づいてステップDにおいて現在特定された前記神経回路網の構造から候補を選択し、この候補に少なくとも1つの遺伝子的オペレーターを適用して、前記表現に基づく現世代の回路網の青写真として特定される新しい世代の回路網の青写真を生成するステップを備え、

30 I.ステップDに戻り、このプロセスを継続するステップを備えることを特徴とする、神経回路網の設計を合成する方法。

【発明の詳細な説明】

本願発明は特定の適用のために最適化された種々の神経回路網の設計に関連して遺伝子タイプの学習技術を使用する方法に関するものである。

神経回路網の設計におけるこれまでの研究によって、特定の適用に対する適当な回路網の構造および学習規則パラメーターの良好な値を決定することが困難であることが明らかにされた。

40 遺伝子アルゴリズムは、統計的選択および組換えに基づく最適化法である。少数の研究者達(Dolan & Dyer (1987)、Dress & Knisely (1987)、Davis (1988)、MontanaおよびDavis (1989)、並びにWhitley (1988)は、遺伝子アルゴリズムを限定されたやり方で適用し、特定の問題に対する神経回路網を生み出している。例えば、デービス(Davis)およびモンタナ(Montana) (1988, 1989)並びにウィットレイ(Whitley) (1988)は、固定された回路網の構造に与えられた重み(weight)を適合させるのに遺伝子アルゴリズムを使用し

本願発明では、神経回路網の構造の一般的な表現は、遺伝子的学習戦略と関連して、特別注文の神経回路網を設計するための柔軟な環境を創り出している。本願発明が基づいている概念は、回路網の設計を「遺伝子的青写真」として表現することである。ここでは、引き続いて生成されるこのような青写真の複製物の組換えまたは変異によって、異なっているが関係のある回路網の構造がもたらされる。

本願発明を説明するために、本願明細書には、本発明者が実行した特別のクラスの神経回路網の遺伝子的合成用のシステムを記載する。本発明者の現在の実施は、フィードバック接続を有していない回路網構造に限定され、バックプロパゲーション（逆伝達）学習規則を組み込んでいる。しかしながら、本願発明は、任意の回路網モデルおよび学習規則に対して使用することができる。

本願方法は、遺伝子アルゴリズム法を使用して新規な神経回路網を設計するものである。遺伝子アルゴリズム（GA）はロバストな関数最適化法である。その使用は、局所的極小、不連続、ノイズまたは多数の次元を包含する問題に対して、最急降下法より優れていることが示されている。GAの有用な特徴は、拡大縮小が非常に良好で、次元が増大しても性能に対する影響が比較的小さいことである。ある関数に対してGAを適用する第1段階は、パラメータスペース（パラメーター空間）をディジットの（典型的には二進法の）記号列としてコード化することである。このような表現の部分記号列は、最適化中の関数のパラメーターに相当する。特定の個々のビット記号列（即ち各位置に対して0または1を選択したもの）は、その関数のパラメーター空間内の1点を示す。GAはこのような個体の集団を考える。この集団は、各個体に対するその関数の値（一般的には「適合性」と称される）と連係して最適な記号列の検索の状態を表わす。GAは、統計学的にその集団のその関数に関する情報を黙示的に記号化し、その情報を使用して新しい個体を創り出すことによって進展する。その集団は再生産プランに従って周期的に更新される。集団の各々の新しい

「世代」は、まず、前の世代を適合性に従ってサンプリングすることによって創り出される。差別的選択に使用する方法が検索スペースをサンプリングするほぼ最適の方法となることが知られている。新規な記号列は、遺伝子的オペレーターを用いて選択された個体を部分的に変更することによって創り出される。遺伝子的オペレーターの中で卓越したものは、サンプリングした2つの個体の一部分を継ぎ合わせることによって新規な記号列を合成するクロスオーバーオペレーターである。

本願発明の主要な目的は最適化された人工の神経回路網を設計するために上記した新しい方法を提供することである。

本願発明の他の目的および利点は以下の明細書、請求の範囲および添付の図面から明白となる。

図面中：

図1は、本願発明の方法に従って特別の目的用に設計することができるタイプの多層神経回路網を示す。

図2は、「青写真」（種々の神経回路網の設計）の集団がそれらの適合性に基づいて遺伝子アルゴリズムによってどのようにして周期的に更新されるのかを図式的に示す。

図3は、本発明に従ってビット記号列表示によって記載される3層の回路網の1例を図式的に示す。

図4は、本発明の実施を促進するビット記号列表示を示す。

図5は、領域または層0～Nを有する回路網表示の肉眼的解剖を示す。

図6は、領域（または層）の配列およびその間に延びるプロジェクションを示す。

図7は、層の空間的構成を示す。

図8および9は、1つの層からもう1つの層に延びるプロジェクションの標的目標を特定する絶対アドレス化および相対アドレス化の例を示す。

図10から12は、図4の領域特定部分記号列の説明例を示す。

図13は、回路網の層間の連結に関するプロジェクションの特徴を示す。

図14は、本願方法で作られた特定の回路網構造の図式的例を示す。

図15は、本願方法に従う実験で使用される基本的な再生産プランを示す。

図16は、遺伝子的オペレーターの操作例である。

図17は、構成要素に分析されそして例示されている1つの個体を有する本願の実行プログラムでの原則的データ構造を示し、そして

図18から21は、回路網の学習速度に関する実施曲線を示す。

本願方法は図1に示される一般的タイプの多層人工神経回路網10の設計に関するものである。回路網10は3つの層（または領域）12、14および16を有するように示されているが、所望の場合3層より多くまたは1層ほどに少なくとも良い。層の各々は、先行技術の教示に従って計数化ユニット18と関連した可変性の重みを有する連結部19によって結ばれている上記ユニットを有する。

この図面および他の図面では、連結部は前方に供給する方向で示される。しかし乍ら、本願発明はこの構築に限定されることはなく、例えばフィードバック連結部を備えることもできる。

更に、本願明細書に開示された回路網設計法の範囲は図1に示される回路網の設計に限定されない。

図2は、青写真20の集団（例えば、種々の神経回路網のビット記号列の設計）がそれらの適合性に基づいて、遺伝子アルゴリズムによってどのようにして周期的に新しくされるのかを図式的に示している。回路網の適合性

はその価値を問題に対して組み合わせた尺度であり、それは学習速度、正確性並びに回路網のサイズおよび複雑性のようなコストファクターが考慮に入れられる。

本願方法は無作為に作られたビット記号列20の集団で開始する。このようなビット記号列の実際の数はある程度任意であるが、経験的には30から100の集団サイズが計数化負荷、学習速度および遺伝子的速度間の良好な妥協であるように思われる。

神経回路網学習アルゴリズム

神経回路網の学習アプローチは、3つの一般的なカテゴリ、すなわち非管理学習、強化学習、それに管理学習に分けられる。非管理学習では、回路網は環境からの評価フィードバックを受けず、その代わりに受け取った入力の特徴に基づいて内部モデルを進展させる。強化学習では、環境は弱い評価信号を与える。管理学習では、各訓練入力と共に回路網の「所望の出力」が与えられる。本願発明を説明するために管理学習、特にバックプロパゲーション (back propagation) が用いられるが、概念上は、本願発明は任意の学習アプローチと共に使用することができる。

管理学習に使用される入力-出力例のセットは訓練セットと称される。学習アルゴリズムは次のように概略することができる：訓練セットでの各々（訓練-入力、所望-出力）の組では

- 回路網の入力に訓練-入力を適用する。
- 回路網の出力を計算する。
- 回路網の出力≠所望-出力である場合
- そのときには回路網の重みを修正する。

エポックと称される、訓練セット中の完全ループは繰り返し実施される。2つの終結規準の1つまたは両者が通常使用される。即ちエポック中の誤りに関するより低い結合および/または多数のエポックに関する制限が存在し得る。この態様で回路網を訓練することはしばしば時間を非常に消費する。より良い学習技術が利用可能になるまでは、訓練フェーズを「オフライン」の活動として計画することが最良である。一度訓練すると、回路網は使用することができる。操作フェーズ中の上記回路網の計数化要求は通常、多くの興味のある適用に対する基礎的なハードウェアだけで満足させることができる。

我々が一般に実行している神経回路網学習アプローチは周知の逆伝達アルゴリズムである。(Werbos, 1974; Lee & Cui, 1986; Parker, 1985; Rumelhart, Hinton & Williams, 1985)。

逆伝達アルゴリズムは付表Bに記載する。

青写真表示

本願発明は主として、構造と学習規則の双方を特定する青写真表現20と、どのように遺伝子的オペレーターを用いて有意義で有用な回路網の構造を構築するかを決定する遺伝子アルゴリズムパラメータと、特定の適用に対する回路網の適合性を決定する評価関数に向けられて

いる。

回路網10の神経回路網構造に対するビット (bit) 記号列表示20の発現は本発明の概念に係わる主要課題である。生物学的神経回路網は合成回路網の明白な指針をもたらすのに十分な程には未だ理解されておらず、そして回路網構成および操作をパラメータ化するためには他の多くの異なる方法が存在する。

特定化された神経回路網の青写真表現またはビット (bit) 記号列20は、理想的には、無効なまたは無意味な回路構造を排除する一方、潜在的に「関心のある」回路網、すなわち有用な作業を行い得るものを捕らえることができない。与えられた問題に対する最良の解決を確実に含む回路網構造の最小の可能な検索スペースを特定することは明らかに有利である。遺伝子アルゴリズムとの関連におけるこの目標の重要な意味は、その表現体系が遺伝子的オペレーターのもとで閉じていなければならないことである。換言すれば、回路網の青写真の組換えまたは変異は、常に有意義な新しい回路網の青写真を生み出さなければならない。表現力と、無効なまたは関心のない構造を容認することとの間には、難しいトレードオフがある。

図3は、3層からなる回路網の各層が、本願発明による表現方法にしたがい、3つの部分記号列17からなるビット記号列表現によってどのように記述されるかの一例を図式的に示している。1つの部分記号列17のフォーマットは図4で更に詳細に示される。

部分記号列層または領域17（領域0から領域N）を有する多層回路網表示20を肉眼的に解剖したものを図5で示す。概念的には、1つの回路網のパラメータは全て、図5の表示20である1つの長いビット記号列中にコードされる。パターン化された棒線は個々の領域または層断片17の開始および終了を示すマーカーである。

本願明細書で使用される用語プロジェクション (projection) は、図1および3の回路網表示におけるような回路網層の計数化ユニット18間に延びる連結部19のグループ化したものまたは組織を称する。

図1では、層12への入力連結部は1本の入力プロジェクションを示し、そして層16から外部に延びる出力連結部は1本の出力プロジェクションを示す。同様に、層12と14間の連結部19は1本のプロジェクションを示し、そして層14と16間の連結部19は1本のプロジェクションを示す。

特別回路網のプロジェクション配列の1例は、層または領域31から35について示されるプロジェクション22から28を有する図6で示される。重要なことは、層32がそれぞれ層33および34に延びる2つのプロジェクション24および25を有することである。更にまた重要なことは、層35がそれぞれ層33および34からのプロジェクション26および27を受け入れる逆の配列があることである。

プロジェクションの各々は、各プロジェクションが特

定の2層間に延びる、予め定められたかまたは所望の多数の連結部19からなることを意味する3つの線で表わされる。

図4を参照して、この図で示される領域または層特定部分記号列17が図1の回路網10の層12、14および16の各々に適用可能であることは明白である。

それ故、ビット記号列20は部分記号列17の1つまたはそれ以上の断片からなり、該部分記号列の各々は層または領域およびその導出結合またはプロジェクションを表わす。各断片は次の2つの部分からなる領域特定部分記号列である：

- 長さが一定で、そして領域または層のアドレス、領域または層中のユニット18の数およびそれらをどのように組織するかに関してパラメーター化する領域パラメーター特定 (APS)。
- 各々の長さが一定の1つまたはそれ以上のプロジェクション特定フィールド (PSFs)。このようなフィールドの各々は1つの層からもう1つの層までの連結部を言う。層の数はこの構造では固定されていない（連結されてはいるが）ので、このフィールドの長さは必要なプロジェクション スペシファイヤー (specifier) の数とともに増加する。プロジェクション（例えば、図6のプロジェクション22から28）は標的領域のアドレス、領域に対するプロジェクションの連結度および次元等によって特定される。

任意の数の領域17が存在するという事実から、APSの開始および終了並びにPSFsの開始を指定するようにビット記号列を有するマーカーの使用が動機づけられる。マーカー読み取り機プログラムが良好に形成された任意の記号列を有意義な神経回路網構造に分析できるようにする。同じマーカーによって、特別の遺伝子的クロスオーバーオペレーターは、「ナンセンス記号列」を生じさせることなく、新しい回路網を見出すことができる。マーカーは「メタ構造」と考えられる。それらは枠組みの役割を果たすが実際にはどんなビットも占有していない。

図4は、APSおよびPSFが本発明者の本願の表示でどのように構成されているかを示す。個々のパラメーターを示すビット記号列の部分は図の標識された箱である。それらは或る一定数のビットからなる部分記号列である。区間スケール（例えば0、1、2、3、4）によって記載されるパラメーターによってグレーコード化が使用できるので、基礎になっているスケール上に近接している値はビット記号列の表示中で近接することができる (Behke, 1980, Caruana & Schaffer, 1988)。

APSでは、各領域または層は名称として使用できる識別番号を有する。名称はビット記号列の領域中で特有のものである必要はない。入力および出力領域は本願明細書の実施態様では一定の識別を与えるもの (identifier)、0および7を有する。

領域はまた、サイズおよび空間的構成も有する。「総サイズ」パラメーターはその領域がどの位多くの計数化ユニット18を有しているのかを決定する。それは0から7までの範囲であり、実際のユニット数のログリズム（底は2）と解釈される；例えば、総サイズが5である場合、32のユニットが存在する。3つの「次元割当て」パラメーター（これもまた底が2のログリズムである）はユニットに空間的構成を課す。領域のユニットは、図7で示されるように、一、二または三次元の直線で囲まれた範囲を有することができる。

この構成の動機づけは、神経回路網が明らかに良好に適合している種類の知覚問題から生じる。例えば、イメージ処理問題は最適には正方形配列で使用されるが、音響解釈問題はベクトルを必要とする。更に常套的な試みでのユニットの構成はしばしば言外に含まれたままである。本願発明では、次元性は図6のプロジェクション22から28のようなプロジェクションの構造に関して明確な言外の意味を有する。

ビット記号列の領域断片のPSFは、当該層中のユニットの出力が遠心的連結部を作る（作ろうとする）場所およびどのようにして作るのかを決定する。表示系は普通にあるような単純なパイプライン構造を想定している訳ではない。例えば、図6は5領域の回路網を示し、その際プロジェクションは第2の領域から2つに分かれ、そして第5の領域で再び接合する。

各PSFは標的領域の同一性を示す。現在これを実施できる2つの方法が存在し、それらは各PSFでの二進法のアドレス表示モードパラメーターの値で識別される。

「絶対」モードでは、PSFのアドレスパラメーターは標的領域のID番号であると理解される。絶対アドレス表示の幾つかの例は図8で示される。

「相対」モードはアドレスビットが現在の領域に関連する、ビット記号列中に標的領域の位置を有していることを示す。ゼロの相対アドレスはプロジェクションを有するものの直後の領域を言う； n の相対アドレスは、存在する場合には、上記領域を越える n 番目の領域を言う。青写真の最後を越える領域を示す相対アドレスは青写真の最終領域—出力領域を言うように理解される。相対アドレス表示に幾つかの例は図9で示される。

種々のアドレス表示系の目的は、領域間の関係を発展させ、そして遺伝子アルゴリズムの再生産計画での発生によって支持され且つ一般化されることを可能にすることである。詳細には、アドレス表示系は、これらの関係がクロスオーバーオペレーターを、無傷かまたは有用な修正を加えるかのいずれかで、生き延びさせ得るように設計される。絶対アドレス表示は、標的が新たな個体の染色体中で巻き付いている場合でも、プロジェクションに標的を示させる。相対アドレス化は、たとえ領域のIDが変わったとしても、ビット記号列中で近接する領域がプロジェクションを維持するようにする。

図10から12を参照して、次元半径パラメーター（これも底が2の対数）は領域中のユニットが標的領域中に局在した群のユニットにだけ突き出るようにさせる。この特徴によって、標的ユニットが受容フィールド29を局在させることができ、これらは共に生物学的神経回路網で共通であり且つハードウェアの実施展望から大いに望ましい。受容フィールド29内であっても、1つの領域または層ともう1つとの間のプロジェクションは必ずしも完全な関数関係を意味しない。プロジェクションの連結密度パラメーターは30%から100%の間の連結性の8段階のうちの1つを規定することができる。

この時点で、ユニット18および連結部19に関する数字の大きさのため、典型的な系ではその数字はそれらの対数で表わされることが予想されると述べるができる。部分記号列17の例を示している本願明細書の図10から12および15で、翻訳された数字は本概念の理解を助けるように説明のために使用されている。

プロジェクションは1組の重みをかけた連結部を有する。重みは回路網の訓練中に学習規則によって調節される。パラメーターはプロジェクションの重みを調節する学習規則を制御するためにPSF中に含まれる。イータ (ϵ) パラメーターは逆伝達の学習速度を制御し、そして0.1から12.8の間の8つの値のうちの1つを有することができる。イータは訓練中一定である必要はない。別のイータスロープパラメーターは訓練エポックの関数としてイータの指数的低下の速度を調節する。

3層の回路網を特定するためにこの表示系をどのように使用できるかは図3に示す。

回路網の最初および最後の領域または層は特別の地位を有している。第1の領域、即ち入力領域は、回路網の環境、實際上入力刺激によって「拘束される」末端のセットを表わす。最終領域は常に出力領域であり、そしてプロジェクションは有していない。

本願明細書に記載した神経回路網のBNFの青写真表示は本願明細書の最後の付表Aである。これに対する将来の修正や追加があることが予想される。

図10から12は、半径および連結密度パラメーターに関するプロジェクション特定部分を説明する、部分記号列17の3つの例を示す。これらの図は、層または領域1から層または領域2へのプロジェクション21の例を示す。図10のプロジェクションは一次元領域（領域1）から二次元領域（領域2）に延び、そして図11および12のプロジェクションはそれぞれ一次元領域（領域1）から他の二次元領域（領域2）に延びている。

図10では、示されたプロジェクションは計数化ユニット18のプロジェクション配列29の 8×4 に対しており、そして普通にはこの配列は垂直方向の半径4および水平方向の半径2を有していると考えられる。対象配列29は領域1の供給源ユニット18aに関して対称的に並んでいる。プロジェクション配列19の境界内のどのユニットも

連結しているため、連結密度パラメーターは100である。

領域1の計数化ユニット18の各々は同様にそれぞれ領域2のユニットの 8×4 のプロジェクション配列との連結を有していると理解され、領域2はプロジェクション配列を実質的に重複させて非常に密集した連結系をもたらす。

図11では、プロジェクションは20のユニットの線状配列の1つおきに対してしている。半径は示された8であるが、半径内のユニットの半分しか連結されていないため、連結密度パラメーターは50である。

図12は、配列中の計数化ユニットが全て連結されておりそのため連結密度が100である点を除いて図11と同様である。

図11および12は、領域1中の各ユニットが領域2中のユニットのそれぞれのプロジェクション配列に連結されていることに関して図10と類似している。

一定の供給源ユニットからのプロジェクションの可能な標的ユニットは3つの次元に沿った半径で決定される。図13はこれの2つの次元の例を幾つか示す。

図14は、本願方法で作られる特定の回路網構造の図式的例を示す。

遺伝子アルゴリズムの適合化

本願方法で使用する遺伝子アルゴリズムの翻訳には、ホランド (Holland) (1975) が「タイプR」と記載したものに類似する再生産プランを使用する。新しい各世代を生じさせる基本プランは図15に示す。サンプリングアルゴリズムはペーカー (Baker) (1987) の確率的普遍的サンプリング系に基づいている。これはその効率性および偏向の欠如のため好ましい。この詳細は本略図で示されていないものもある。最終工程は、世代 i の最良の個体が世代 $i+1$ で確実に常に保持されるように加えた。

遺伝子アルゴリズム (GA) それ自体は多数のパラメーターを有する。それらの良好な値が、このシステムを効率的に操作するうえで重要である。これらのパラメーターには、集団サイズ、種々の遺伝子オペレーターを適用する割合、および合成環境学の他の局面が含まれる。

2つの遺伝子的オペレーターとしては、クロスオーバーおよび変異オペレーターが使用された。クロスオーバーオペレーターは、現世代の2つの回路網の青写真の同相断片を有効に交換し、次世代の1つの回路網に対する青写真を作る。遺伝子アルゴリズムの適用の大部分では、ビット記号列中の絶対位置によって、同相断片を識別することができる。例えば、 N 番目のビットが、常に任意の個体内の同一の特徴を特定するために使用される。本願における表現は可変長の記号列を認めているので、上述した記号列マーカを参照して2つの個体の同相遺伝子座位を決定した、修正2点クロスオーバーオペレーターを使用した。より一般的的な1点クロスオーバー

ーとは対照的な2点クロスオーバーを使用することとしたのは、この方法でオフライン実行が改善できたという、ブーカー (Booker) (1987) のレポートによって動機づけられた。

変異オペレーターは、同一機能の遺伝子の対立遺伝子代替形態を導入または再導入するのに低率で使用された。遺伝子アルゴリズムの現在の適用は、 10^{-2} またはそれ以下のオーダーの割合で、変異による有効な寄与を示した。

遺伝子のオペレーターのもとで閉じたビット記号列表現を意図して設計したという事実にも拘わらず、一見したところ受容できない個体をGAが発生させることがある。臆面のない例は、入力から出力へのプロジェクションのパスウェイを有していない回路網プランである。より微妙な問題は、我々のシミュレーション能力の限界から生じる。本発明者の初期の研究では、再現性が限られ、また、フィードバックを有する回路網プランは単純な逆伝達 (バックプロパゲーション) のもとでは耐えられない。これらの不適格なものの重荷を最少にするため、2つの戦略を使用した。第1に、再生産プランで致命的な異常を有する個体を間引く入力から出力領域へのパスウェイを有していない個体はこのグループの大半を占める。第2に、小さな異常を有する青写真はそれらの回路網実施で「浄化」する、即ちそれらの欠陥を除去する。

図16は、クロスオーバーオペレーターがどのようにして両親と異なるフィールド値を有する新しい記号列を創るのかの例を示す。ここで、該フィールドは単純な二進法コード化系を使用すると仮定する。

合成した回路網の評価

回路網の適合性を測定するために使用された評価関数が適当である場合にのみ、世代を通じた適切な改善を達成することができる。適合性の測定は、GAが更により良い回路網を作るのに必要である。評価関数で特定される青写真表現スペース上の面を最高のピークを特定しようと精査することとして、このアルゴリズムに思いを巡らすことは有益である。

上記した評価関数の要件に従って、本発明者は最初に評価関数を実施メトリックス (metrics)、Piの重みづけした合計として公式化した。個体iの評価関数、F (i)、は：

$$F(i) = \sum_{j=1}^n a_j p_j (i)$$

と表すことができる。

係数 a_j は回路網の所望の特性を示すように使用者が調整することができる。今まで考慮してきたメトリックスは、観察された学習速度およびノイズのある入力での回路網の実施のような実施ファクター並びに回路網のサイズおよび形成される連結部数のようなコストファクター

を含んでいる。実施規準は適用から適用まで変化するの、本発明者は種々の実施およびコストファクターの混合物を採用した。各ファクターでの相対的重みは修正することができるので、回路網構造は種々の最適化規準に合わせて変えることができる。例えば、本発明者の目標の1つが計数的に有効な回路網を合成することである場合、サイズメトリックスは負の重みを与えられるかも知れない。他方、正確性およびノイズ耐性が更に重要である場合には、ノイズのある入力パターンでの実施はより高い重みを与えられるのであろう。

GA実施の評価

有用な構造を見出す際の遺伝子アルゴリズムの実施 (回路網それ自体とは全く異なって) について結論を出すために、本発明者はそれを比較するために成る規準を求める。この問題に直接関係する発表されたデータがないように思われるので、上記のことは困難である。本発明者の試みは、回路網青写真を無作為的に発生させ、評価し、そして最上のものを保持する制御研究を行うことである。これは、クロスオーバーおよび変異の遺伝子的オペレーターを単純に「ターニングオフ (turning off)」することによって実施される。無作為検索は、他の検索アルゴリズムがその価値を証明するために越えなければならない、しばしば使用される実施のベンチマークである。

データ構造

本発明の現在の実施での主要なデータ構造は、操作時に創られそして一緒に結合される対象である。最も優れた対象は、現在の集団、何世代にも亘る実施歴、並びに種々の制御およびインターフェース (interface) パラメーターを維持する「実験」である。この実施歴は記録のリスト、即ち世代ごとのリスト、注意書き、特に、オンライン、オフライン、平均および最高スコアのリストである。集団は図17で示される現在の個体からなる。

各個体は連合した青写真を有しており、それは1束のビットベクトルとして貯えられる [ビットベクトルは各要素が機械の記憶中で1つのビットを占有する一次元配列である]。

ビットベクトルは、BNFで示されるように、2つのタイプ、即ち領域 (APS) およびプロジェクション (PSF) である。各タイプの構造はリスプ (Lisp) 形態で定義されており、各フィールドの名称および占有すべきビット数を示している。例えば、プロジェクション特定は次のとおり定義される：

(定義-ビットベクトル)	プロジェクションスペース
(半径-1)	3)
(半径-2)	3)
(半径-3)	3)
(連結-密度)	3)
(標的-アドレス)	3)

15

(アドレスモード 1)
(初期-イータ 3)
(イータスロープ 3))

この形態は各パラメータの値を任意の一定のビットベクトルから取り出すのに必要なアクセッサを自動的に定義する。アクセッサはフィールドのグレーコード化および解読を実施する。フィールドの整数値の大部分は索引テーブルから穿孔解釈される;例えば、イータテーブルは0.1~12.8から値0...7~イータを翻訳する。

クロスオーバーおよび変異のような遺伝子のオペレーターはこのビットベクトル青写真を直接修飾し、これは個体用のマスタープランと考えられる。その断片は実際その子孫に共有される。しかし乍ら、ビットベクトルは実際の神経回路網の実施には直接有用でない。このために、個体を分析し、純化し、そして例示しなければならない。

個体を分析したとき、青写真のビット記号列形態は各領域に対しては節一領域節、各プロジェクションに対してはプロジェクション節の回路網中に翻訳される。分析はプロジェクションでなされる領域間アドレス化をなし、遂げ、そして節は関連したビットベクトルから解釈されるパラメータ値を有している。回路網または分析された青写真は個体を表示する対象と関連している。

分析された青写真は、神経回路網としての有意義な解釈を妨げるという欠点を有することがある。例えば、有効な標的を有さないプロジェクション、またはフィードバック回路を示すプロジェクションを有することがあり、これは本願の実施では禁じる。僅かに不完全な個体を廃棄するのではなくて、分析した後にそれらを継ぎ合わせる試みがなされる。継ぎはぎ工程は純化と呼ばれる。ピュリファイヤー (purifier) は、変化を出来るだけ少なくし乍ら懸垂節を除去しそして回路を切断して生存可能な個体を創ろうとする。

分析および純化後に、個体は例示される。例示にはユニット用ベクトル、重みマトリックス、マスクマトリックス、閾値ベクトルおよび他の数値記憶装置を割り当てることおよび開始することが含まれる。これらのデータ対象への照合は個体の分析された青写真の節中に保持される。

評価プロセス

分析/純化/例示配列の目的は個体の評価、即ちスコア計数化用の段階を定めることである。スコアは1組の実施メトリックスの重みづけした合計である。重みは操作時に使用者が定めることができる。

これらメトリックスの幾つかは例示の直接的結果、例えば重み数、ユニット数、領域数、および平均ファンアウト (fan-out) である。他のメトリックスは一定の問題 (ディジット認識のような) に関する個々の回路網実施によって決まる。このようなメトリックスの例は: 回路網の学習速度、訓練セットでの最終実施、非低下入力

16

および新規入力での実施、並びに回路網の重みかまたははユニットかのいずれかの無作為標本を一時的に多層化した後の実施である。

結果、分析および考察

初期の実験の限られた範囲にも拘わらず、本願方法は合理的な回路網を作り、そしてその第1世代での偶然の構造以上の有意の改善を達成した。殆どの場合、作られた回路網は構造的には全く単純であった。

実施規準

遺伝的最適化系での期間を通しての集団実施での変化を捜すためには幾つかの共通の方法があり、そして本発明者のチャートの大部分には4つの系がある。本発明者の再生産プランが再生産および評価の別々のフェーズを通過するので、データポイントは実際には各世代の最後に記録される。

Siは生じたi番目の個体のスコアである。ベスト関数は一定時間までのGAによって見い出されたベスト個体の実施を示す、即ち

ベスト(i) = Max [Sj, j = 1, ..., i]

オフラインGA実施は一定時間までに見い出されたベスト個体スコアの平均である:

$$\text{オフライン}(i) = \frac{1}{i} \sum_{j=1}^i \text{Best}(j)$$

別法はオンライン実施である。これはこれまでに評価した全個体スコアの単純平均である。時間iの最後に、これは次のようになるであろう:

$$\text{オンライン}(i) = \frac{1}{i} \sum_{j=1}^i S_j$$

もう1つの興味ある関数は一定の世代の個体の全ての平均スコアである。Giがi番目の世代の個体のセットである場合には:

$$\text{平均}(i) = \frac{1}{|G_i|} \sum_{j \in G_i} S_j$$

オンライン実施は多分、リアルタイムの方法と相互に作用しなければならない系と最も関係があり、一方オフライン実施はベストを見つけることだけに関係があって探すのにどの位コストがかかるかには関係がない。例えば、ウマを選ぶ場合、勝馬のみならず負け賭金の全てを考慮に入れることが重要であり、オンライン実施の関心を動機づける。関数を最適化する場合、唯一の関心は試験したベストポイントの品質に関するものであり、オフライン実施を動機づける。「ベスト」および「オフライン」関数が定義によって一本調子であることに注目して、それらは実験経過中唯増加するだけかまたは一定のままであり、そして減少することはない。

実験1

適用: デジタル認識

最適化規準: 学習曲線下の領域

集団サイズ: 30

世代数: 60

回路網集団の平均実施は第1世代から第6世代までに8倍に増加した。回路網は48のエポックで規準を学習した。

唯一つのファクターだけが直接最適化されていたので、重みの数のような他のファクターは自由に变化させた。回路網は1481個の重みを有していた。各入力を各出力と連結している1つの重みを正確に有している回路網は多数の重みとしては第3のものしか有していなかったであろう。このような回路網も作られ、そしてこれらは同様に完全に学習したが2倍以上長い時間を要した。この60世代実験の本実験の実施は図18で要約する。

第1世代では、隠れた層の構造が存在した。この問題を直線的に区別できることは、実験が完全に学習した2層構造を作り始めるまで本発明者には明白でなかった。隠れた層はこの問題には必要でなく、そして一般的に学習速度は隠れた層が回路網に加えられるにつれて低下する(この低下は我々が使用している修正された逆伝達規則 [Samad, 1988] では元の規則よりはるかに厳しくない)ので、シミュレーションの終りには多層構造はまれであった。

より良い回路網を見い出す際のGAの実施を評価するために、デジタル認識問題はGAが無効になった状態で反復した。これを達成するために、無作為個体をクロスオーバーまたは変異が適用される場所で発生させた。更に、スコアは専ら学習曲線下の領域に基づいた。この実験の結果は図19で図表にする。

無作為検索およびGA実験は0世代に非常に類似した集団で開始したが、2つのアルゴリズムの実施は間もなく分岐した。特に、無作為検索アルゴリズムの平均的でオンラインの実施はGAよりはっきりと劣っていた。より良い特性の幾つかを1つの世代から次の世代に成功裏に保持している場合、上記のことが予期される。即ち無作為検索方法はかなりの一定速度で「敗者 (losers)」を選ぶことに集中される。オフライン実施はGAおよび無作為検索間のこの問題に対する一層興味のある比較であると十分論証できる。図20は図18および19から抜き出したオフライン実施を示す。

更にもう1度、GA実施は実験期間中無作為検索より優れている。その差は大きいものではないが、述べられているように、そのスコアは標準化されると主張することができよう。60世代後に見い出された(偶然に)最高の回路網はその問題を学習するのに67のエポックを必要とし、一方GAで見い出された最高の回路網はその問題を40のエポックで学習した。更に、本発明者には、変更した表示およびより良いパラメーター値によってGAの実施を

改良することはできるが、無作為検索方法の実施では改良の許容度はないように思われる。最後に、予告: 本発明者は比較的小さい集団で実施しており、本発明者の実験は2,3の世代に限定され、それ故これらの結果は全て注意して解釈すべきである。

実験2

適用: デジタル認識

最適化規準: 平均ファンアウトおよびパーセント補正

集団サイズ: 30

10 世代数: 20

この実験では、規準は同等に重みをかけた(0.5)平均ファンアウトおよび百分率補正であった。学習速度はスコアに関してどんな直接的影響も受けなかった。訓練後の正しいデジタル識別の百分率は訓練された回路網に10個のデジタルの各々を示すことによって、そして最大値を有する出力ユニットが正しいデジタルに相当する場合には「ヒット (Hit)」を記録することによって決定した。平均ファンアウトはユニット数に対する重み数の比として定義される; このメトリックは標準化されそして転化されるので、ユニットに対する大きい比率の重みは個体のスコアを減じるであろう。この実験で提示された問題は、該系がファンアウトを制限することによって実施を改良することができるか、ということである。それは、高いファンアウトがシリコンで操作するのが困難であるので、神経回路網ハードウェアの設計者に興味のある質問である。[平均ファンアウトは、更に一層興味のある量—最大ファンアウトの概算である。] 本発明者の最初の結果を図21に示す。

この実験での平均ファンアウトは $157/48=3.27$ であった。これは実験1で示された。殆どより高い或るオーダーの大きさの平均ファンアウトを有する回路網と対比できる。

学習は全く緩慢である。事実、上記回路網は、訓練用終結規準として予め特定化された誤謬閾内までは学習しなかった。(誤謬閾内までの学習は完全なヒット速度を達成するためには必要でない。)

回路網の連結性構造は大きい受容フィールドを使用するが連結密度は低い。ハードウェア実施予想から、小受容フィールドを最適化することが更に良いので、このような実験を意図する。

学習速度のメトリック

学習速度用に選択したメトリックは幾らか説明する必要がある。計数化源に制限があるため、本発明者は、全回路網が一定の問題に対して、またはついでに言えば予め決定された任意のノンゼロ規準に対する完全な精度を達成するまでは全回路網を訓練したいとは望み得ない。場合によっては、回路網は100のエポックを必要とし、一方他の場合には100万でも不十分である。本発明者の妥協は学習フェーズを終了させる2つの規準を使用することである。以前のエポック中のrms誤謬が一定の

閾より少ないとき、学習は第1の規準によって終了する。一定数のエポックが計数された後で、学習フェーズは第2の規準によって終了する；この閾は問題に従って実験者によって定められるが、典型的には100から5000の間のエポックである。それにも拘わらず、本発明者は、たとえ個体の訓練が種々の数のエポックの終りまでもちこたえそして種々の最終精度値がもたらされるとし

ても、全個体を同一の学習速度目盛りで比較したい。本発明者の概算は各個体の学習フェーズに亘ってrms誤差曲線を積分することである。この「学習曲線下の領域」は学習速度目盛りに関する本発明者の直感に密接に対応するランクを提供する。より少ない数はより良好な実施を意味する。

付 表 A

BNF の 背 写 真 表 示 用 系 統 的 配 列

<背写真・スペツク> ::= <入力・スペツク><中間・スペツク><出力・スペツク>
 <入力・スペツク> ::= <領域・スペツク><プロジェクション・スペツク>
 <中間・スペツク> ::= 空 (カラ) | <断片> | <中間・スペツク><断片>
 <出力・スペツク> ::= <領域・マーカー><領域・id><次元・サブフィールド>
 <領域・スペツク> ::= <領域・マーカー><領域・id><次元・サブフィールド> |
 <プロジェクション・スペツク>
 <プロジェクション・マーカー><プロジェクション・スペツク・フィールド>
 <断片> ::= <領域・スペツク><プロジェクション・スペツク>
 <領域・マーカー> ::= 空 (カラ)
 <領域・id> ::= <2進法・ディジット群>
 <次元・サブフィールド> ::= <縦・サイズ><dim・スペツク><dim・スペツク>
 <dim・スペツク>
 <学習・規則・スペツク> ::= <イータ・初期・値><変化するイータのスロープ>
 <プロジェクション・マーカー> ::= 空 (カラ)
 <プロジェクション・スペツク・フィールド> ::= <連続性の半径><連結密度>
 <標的アドレス><標的アドレス・モード>
 <学習・規則・スペツク>
 <2進法・ディジット群> ::= <2進法・ディジット> | <2進法・ディジット><2進法・ディジット>
 <上部・結合> ::= <2進法・ディジット><2進法・ディジット><2進法・ディジット>
 <次元・スペツク> ::= 同 上
 <イータ・初期・値> ::= 同 上
 <変化するイータのスロープ> ::= 同 上
 <連続性の半径> ::= <連結の半径><連結の半径>
 <連結の半径>
 <連結の半径> ::= <2進法・ディジット><2進法・ディジット><2進法・ディジット>
 <連結・密度> ::= 同 上
 <標的・アドレス> ::= 同 上
 <標的・アドレス・モード> ::= <2進法・ディジット>
 <2進法・ディジット> ::= 011

付表B
逆伝達

神経回路網は2つの初期エレメント、即ち処理ユニットおよびユニット間の（方向づけられた）連結から構築される。処理ユニットは個々に全く単純であるが、それ

らは十分に連結されている。各連結は典型的にはそれと関連した実際に評価された重みを有しており、そしてこの重みは、連結源でのユニットの値がその結末でユニットに対して有する効果を示している。ユニットの出力はその入力の重みをかけた合計の或る関数である：

$$o_j = f\left(\sum_i w_{ij} o_i - \theta_j\right) \quad (1)$$

式中、 o_j はユニットのjの出力であり、 w_{ij} はユニットiからユニットjまでの重みであり、そして θ_j はユニットjの「閾」またはバイアス重みである。量 w_{ij} *

$$f(x) = \frac{1}{1 + e^{-x}}$$

大部分の逆伝達回路網では、ユニットは層状に配列されており、回路網は非環状であることが強いられる。このような「多層前方供給」回路網は多次元連続入力スペースから多次元連続出力スペースまでのマップ形成を任意に高い精度で実現できることが示される (Hecht-Nielsen, 1987; Lippman, 1987; Lapedes & Farber, 1988)。

重みを修正するために使用される規則は：

$$\Delta w_{ij} = \eta o_i \delta_j$$

である。


これは標準的な逆伝達学習規則である。ここで w_{ij} はユニットiからユニットjへの重みであり、 o_i はユニットiの出力であり、 η は学習速度を決定する定数であり、そして δ_j はユニットjの誤謬期間である。 δ_j は出力領域のユニットおよび「隠れた」領域のユニットで種々に定義される。出力ユニットでは

$$\delta_j = o_j' (t_j - o_j)$$

式中、 o_j' は正味入力に関して o_j から誘導したものであり(式(2)の活性化関数では、この量は $o_j(1 - o_j)$ である)そして t_j はユニットjの標的値(「所望の出力」)である。隠れたユニットでは、標的値は既知でなく、そして誤謬期間は次の「より高い」層の誤謬期間から計数される：

$$\delta_j = \sum_k o_k' w_{jk} \delta_k$$

【第1図】



* $o_j - \theta_j$ は通常はユニットjに対する正味入力を言い、 net_j と記号化される。逆伝達で通常使用される式(1)の形態はシグマの関数である：

$$(2)$$

10 本発明者は本願の実施で逆伝達の最上の使用に2つのエクステンションを導入した。第1に、本発明者は最近見いだされた式(3)の改良 (Samad, 1988) を使用する：

$$\Delta w_{ij} = \eta (o_i + \delta_i) \delta_j$$

この式は本願の計数化値の代わりに重みの供給ユニットの予想値を使用する。場合によっては、非常に速いオーダーの学習が達成される。

第2に、本発明者は学習が進行するにつれて η の値を減少させることができる。即ち、ここで η は可変数であり、そして実際に使用される学習規則は：


$$\Delta w_{ij} = \eta_t (o_i + \delta_i) \delta_j$$

(式中、 η_t は訓練セットによるt番目の反復時の η の値である)である。各反復の最後に、 η は次の式に従って変化する：


$$\eta_{t+1} = \eta_{\text{slope}} \eta_t$$

式中、 η_{slope} は η の低下速度を決定するパラメータである。 η の高い値を最初に使用しそしてそれを徐々に下げることによって一定の η を使用するより有意に速い学習がもたらされることが実験的に観察された。 η_{slope} および η の初期値(η_0)は共に青写真のプロジェクトン特定によって与えられる。

【第2図】




【第3図】



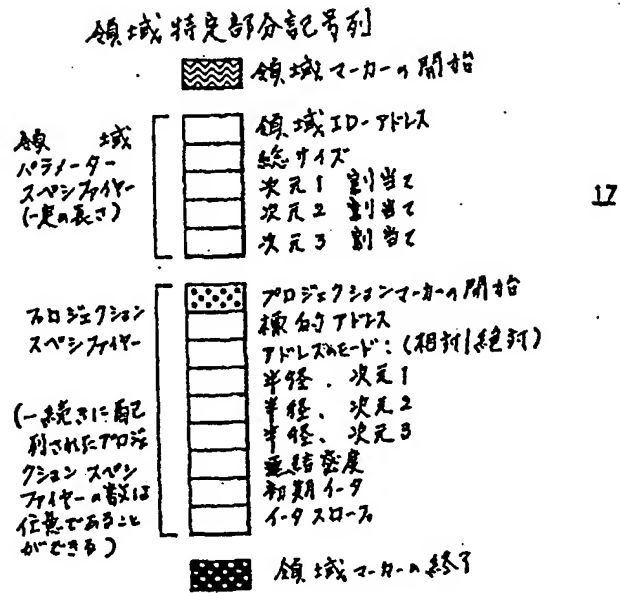
層アドレス 絶対(0)は
入力プロジェクションを特定
するために存在する。
そのユニットは訓練パタン
に固定される。

層アドレス 絶対(7)は
慣行において出力領域である。
それはプロジェクションを
有さなくてもよい。


【第5図】




【第4図】



【第6図】




【第7図】




領域の空間的構成

各々の小さい正方形は1ユニットを表わす。
ラベルは各々の次元の「割当て」を示す。


【第8図】




【第9図】




【第10図】




【第11図】




【第12図】




【第13図】



半径は1x1, 2x2の
ボックスが中心ドットを囲む。
これは、斜線を示すため
1ユニットを完全に包囲する。




半径は2x2, 4x4の
ボックスが中心ドットを囲む。
これは、斜線を示すため
9ユニットを完全に包囲する。



半径は1x2, 2x4の
ボックスが中心ドットを囲む。
これは斜線を示すため
5ユニットを完全に包囲する。

【第14図】

領域1 → 2 → 5 領域3 → 2 → 7 領域5 → 3 → 7 領域7



領域 ID 1
 サイズ 2
 終 1 割当 2
 次元 2 割当 1
 * 次元 3 割当 1
 *
 標的プロセス 2 A
 アドレス 1 1
 * 半径 2 1
 * 半径 3 1
 標的アドレス 2 R
 アドレス 1 2
 * 半径 1 1
 * 半径 2 1
 * 半径 3 1

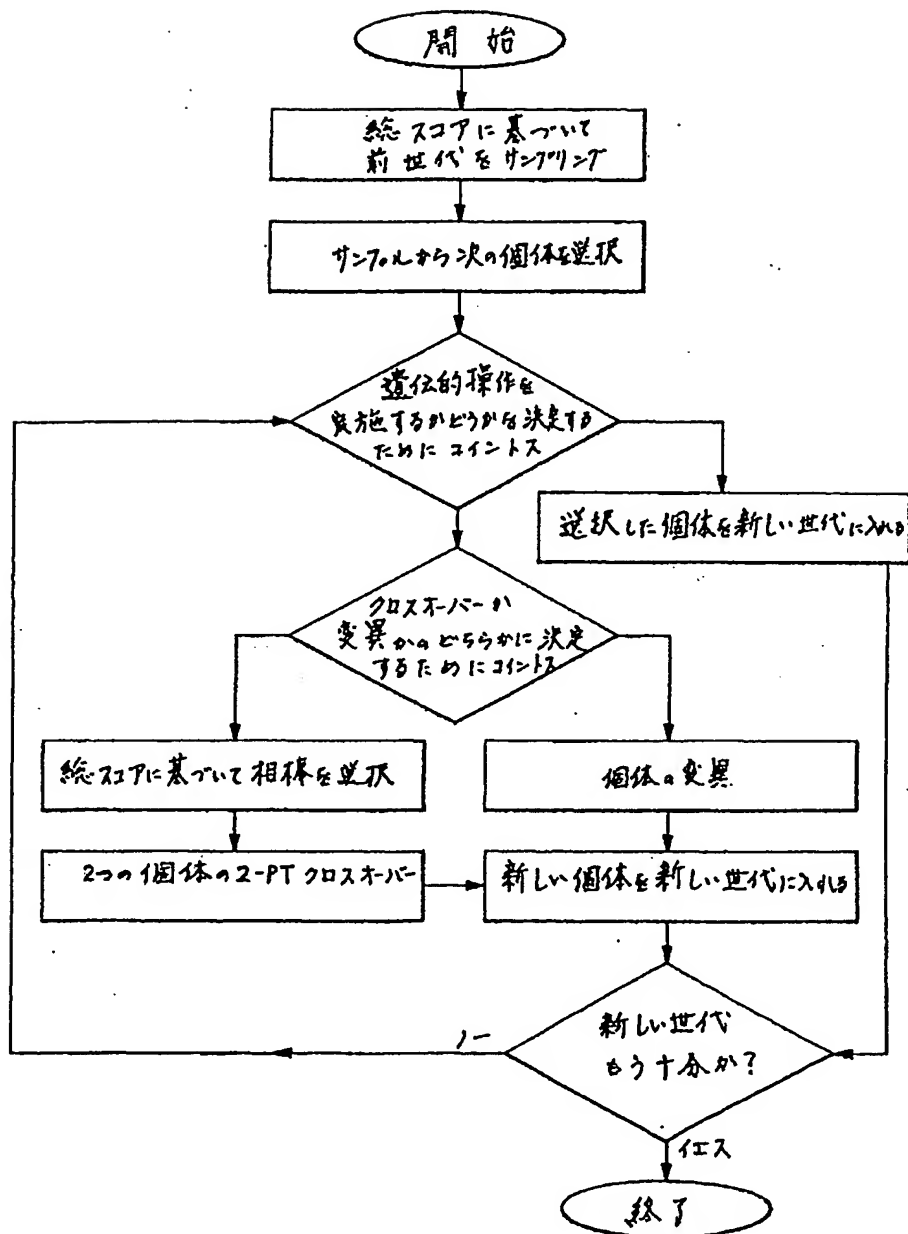
領域 ID 3
 サイズ 8
 終 1 割当 2
 次元 2 割当 1
 次元 3 割当 1
 標的プロセス O R
 アドレス 1 1
 * 半径 1 1
 * 半径 2 1
 * 半径 3 1
 標的アドレス 7 A
 アドレス 1 2
 * 半径 1 1
 * 半径 2 1
 * 半径 3 1

領域 ID 2
 サイズ 1
 終 1 割当 1
 次元 2 割当 1
 次元 3 割当 1
 標的プロセス 3 A
 アドレス 1 2
 * 半径 1 2
 * 半径 2 3
 * 半径 3 1

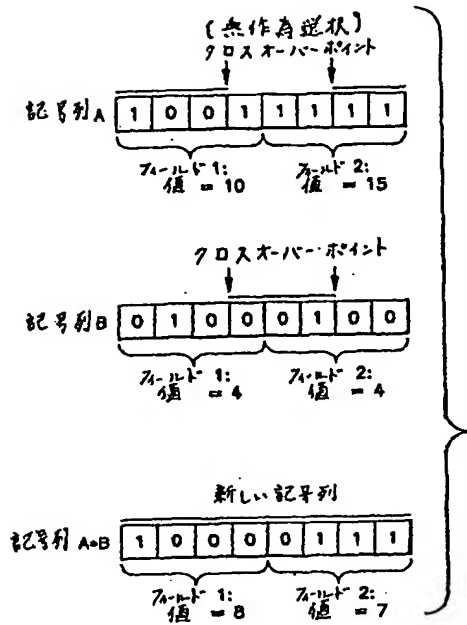
領域 ID 5
 サイズ 2
 終 1 割当 2
 次元 2 割当 1
 次元 3 割当 1
 標的プロセス 7 A
 アドレス 1 2
 * 半径 2 2
 * 半径 3 1
 標的アドレス 3 A
 アドレス 1 8
 * 半径 2 4
 * 半径 3 1

領域 ID 7
 サイズ 4
 終 1 割当 2
 次元 2 割当 1
 次元 3 割当 1


【第15図】




【第16図】



【第18図】

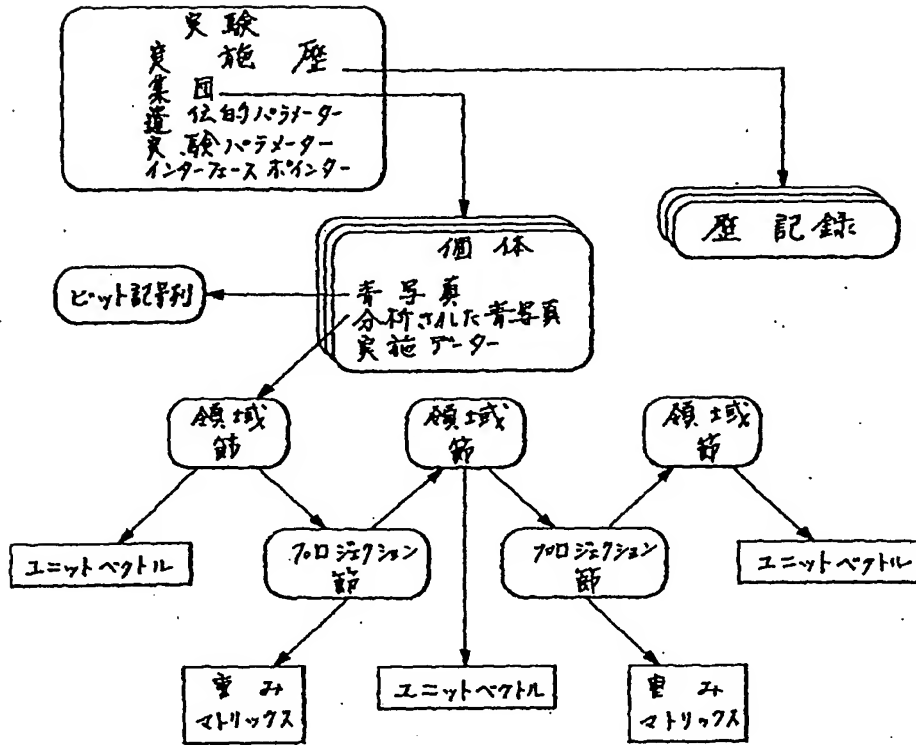


【第19図】




遺伝的オペレータで学習した無作為検索によるテスト認識課題
 に対する実施。
 学習曲線下領域に75%スコアに貢献した。


【第17図】



【第20図】



【第21図】



フロントページの続き

(72)発明者 サマツド, タリク
アメリカ合衆国 55410 ミネソタ州・
ミネアポリス・ラッセル アヴェニュー
サウス・4949

(56)参考文献 Harp S. Samed T. Gu
ha A. "Towards the
Genetic Synthesis
of Neural Network
s," Proceedings of
ICGA-89 (1989. 6)
Miller G. F., Todd
P. M., Hegde S. U., "N
eural Networks Usi
ng Genetic Algorit
hms". Proceeding of
ICGA-89 (1989. 6)

(58)調査した分野(Int.Cl.6, DB名)

G06F 15/18

G06G 7/60

JICSTファイル (JOIS)

THIS PAGE BLANK (USPTO)